

基于分数变换域数字水印的自适应图像溯源技术

孟燕雨¹, 唐雪译^{1,2}, 李维皓¹

(1. 华北计算机系统工程研究所, 北京 100083; 2. 北京理工大学, 北京 100081)

摘要: 随着互联网应用的普及, 图像传播为人们的社交生活和工作提供了便利, 同时也带来了安全隐患, 保护图像拥有者本身的数据所有权成为了当下亟待解决的问题之一。以图像溯源技术中数字水印技术为主要研究对象, 提出了一种基于分数阶变换域的自适应联合数字水印算法, 以分数变换域技术替代了传统变换域技术, 使得数字水印具有更强的鲁棒性。同时, 以自适应地动态选择变换阶数平衡了水印的隐蔽性和鲁棒性, 保证了图像溯源的有效性。

关键词: 数字安全; 数字水印; 图像溯源; 分数阶变换

中图分类号: TP309

文献标识码: A

DOI: 10.19358/j.issn.2097-1788.2024.12.005

引用格式: 孟燕雨, 唐雪译, 李维皓. 基于分数变换域数字水印的自适应图像溯源技术 [J]. 网络安全与数据治理, 2024, 43(12): 33-39.

Adaptive image tracing technology based on fractional transform domain digital watermark

Meng Yanyu¹, Tang Xueyi^{1,2}, Li Weihao¹

(1. National Computer System Engineering Research Institute of China, Beijing 100083, China;

2. Beijing Institute of Technology, Beijing 100081, China)

Abstract: With the widespread use of internet applications, image dissemination has facilitated people's social lives and work, but it has also introduced security risks. Protecting the data ownership of image creators has become a pressing issue. This paper focuses on digital watermarking technology within image tracing, proposing an adaptive joint digital watermarking algorithm based on fractional-order transform domain. By utilizing fractional transform domain techniques instead of traditional transform domain methods, the digital watermark achieves greater robustness. Additionally, by adaptively selecting the transformation order, the algorithm balances the watermark's invisibility and robustness, ensuring the effectiveness of image tracing.

Key words: digital security; digital watermark; image traceability; fractional order transform

0 引言

随着互联网技术的不断发展, 图像传播已经成为了网络通信中的一个重要环节。数字图像作为一种具有高附加价值的内容, 其广泛的传播为人们的生活和工作带来便利的同时, 也带了信息安全和版权保护等问题。如何在图像传播的过程中保护图像拥有者的数据所有权, 是一个亟待解决的重要问题。数字水印可以在不影响图像本身使用价值的前提下, 在图像中隐蔽地嵌入水印信息以标识数据拥有者的所有权, 更好地兼顾了水印的隐蔽性和安全性。在医学图像领域中, 数字水印可以用于标识患者信息, 以避免由于信息匹配错误造成的医疗事故^[1]。脆弱的数字水印还可以应用于图像篡改的检测与识别, 通常将鲁棒性极低的数字水印嵌入到图像中, 通

过提取并检查水印的变化来检测图像是否遭到篡改^[2]。

传统的数字水印技术主要分为空域技术和频域技术^[3]。空域技术直接在像素、采样值等空间域数据上进行操作以实现水印的嵌入, 实现过程简单但水印的鲁棒性较差。频域技术在图像的变换域上进行水印嵌入, 嵌入的水印通常具有更好的鲁棒性, 在实际应用中是主流方法。分数阶变换域方法是传统变换域方法的推广, 基于分数阶变换的数字水印技术通过引入分数阶参数, 灵活地在时域和频域之间平衡信号的表示, 提供更多的自由度以增强水印算法的适应性, 相比于传统水印方法具有显著的优势, 在鲁棒性、灵活性和安全性方面表现更好。基于变换域的水印方法比基于空间域的水印方法具有更好的鲁棒性^[4]。相比于传统变换, 分数阶变换提供

了更高的灵活性,但现有分数阶变换数字水印的研究多采用固定阶数,关于分数阶变换的阶数选择的研究还较少。

随着人工智能技术的高速发展,机器学习等技术也逐渐被应用到数字水印中来。近年来深度学习数字水印方法也取得了许多成果,深度神经网络、循环神经网络、卷积神经网络和生成对抗网络等深度学习模型被广泛应用于水印技术中。但现有的人工智能方法的应用多聚焦于水印的嵌入过程或提取过程,用于学习在空间域或变换域上如何更好地嵌入或提取水印,如何利用深度学习等人工智能技术更好地选择分数阶变换域方法的阶数,这一问题仍有待研究。本文希望使用分数阶变换域方法替代传统变换域方法,并且结合深度学习自适应地动态选择变换阶数,以更好地平衡数字水印的隐蔽性和鲁棒性。

1 概述

1.1 基本概念

1.1.1 分数阶变换

分数阶变换(Fractional Order Transform)是一类基于分数阶微积分理论构建的信号变换方法,是信号处理领域中的重要工具^[5]。它通过将传统的傅里叶变换、拉普拉斯变换等整数阶变换推广到非整数阶,使得信号分析在时频域具有更高的灵活性,能够在时域和频域之间实现平滑过渡,获得更丰富的时频信息。

定义 1 一维信号 $x(t)$ 的 p 阶分数傅里叶变换从积分变换角度的定义为^[5]:

$$X_p(u) = F^p[x](u) = \int_{-\infty}^{+\infty} x(t) K_p(t, u) dt \quad (1)$$

其中 F^p 是分数傅里叶变换算子,核函数 $K_p(t, u)$ 的表达式为

$$K_p(t, u) = \begin{cases} A_\alpha e^{i(t^2\cot\alpha/2 - \omega t\sec\alpha/2)}, & \alpha \neq n\pi \\ \delta(t-u), & \alpha = 2n\pi \\ \delta(t+u), & \alpha = (2n \pm 1)\pi \end{cases} \quad (2)$$

其中 $A_\alpha = \sqrt{(1 - \cot\alpha)/2\pi}$, $\alpha = p\pi/2$ 代表时频平面的旋转角度。式(1)既可称作是信号 $x(t)$ 的 p 阶分数傅里叶变换,也可称作是信号 $x(t)$ 在 α 角度下的分数傅里叶变换。

1.1.2 分数阶变换数字水印

与传统的整数阶变换相比,分数阶变换具备更高的灵活性^[6]。分数阶变换可以通过调整阶数在时域和频域之间实现平滑过渡,使得水印可以灵活地选择嵌入位置和频率范围,这种灵活性使得水印在应对旋转、缩放、裁剪等攻击时具有更好的适应性和抗攻击能力。此外,

分数阶变换能有效结合信号的时域和频域信息,通过对水印嵌入的时频特征加以调控,从而增强水印的不可见性和鲁棒性。

分数阶变换数字水印技术适用于版权保护、内容认证和数据防伪等应用场景,通过在图片、视频、文档等载体信号中嵌入分数阶水印信息,能够在保障信息安全性的同时,避免对原信息的明显篡改。分数阶水印技术表现出了较强的鲁棒性和隐蔽性,但也面临一些挑战,例如抗几何攻击能力的增强、计算复杂度的优化以及自适应嵌入算法的改进。图 1 所示为数字水印的基本内容示例。

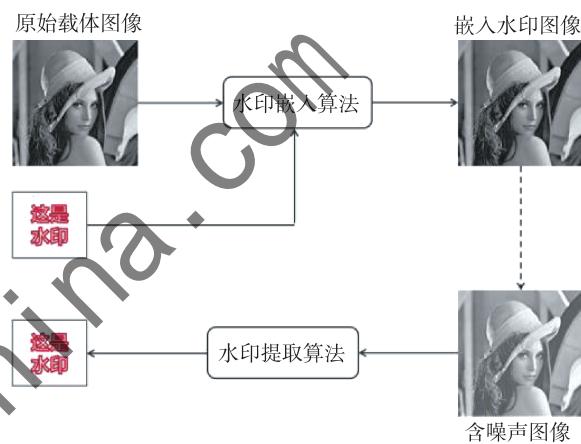


图 1 数字水印示例

1.1.3 深度学习数字水印

如图 2 所示,深度学习数字水印是结合深度学习技术来实现数字水印的嵌入、提取和检测的水印方法,它在隐蔽性、鲁棒性和自动化方面表现出显著优势^[7]。传统的数字水印通常通过离散余弦变换、离散小波变换等频域或空域的变换来嵌入水印信息,而深度学习数字水印则借助卷积神经网络(Convolutional Neural Networks, CNN)、生成对抗网络(Generative Adversarial Networks, GAN)等深度学习模型,自动学习并优化水印的嵌入位置和方式,从而在保证水印隐蔽性的同时提升鲁棒性。

深度学习数字水印的基本原理是将水印信息作为输入数据,通过深度网络将其嵌入到载体信号中,如图像、音频或视频文件,并使用逆网络结构或判别网络来提取或检测水印。利用深度学习的特征提取和表示能力,水印的嵌入和提取可以适应多种复杂的攻击,从而显著提高了水印的稳定性和抗攻击能力^[8]。深度学习数字水印广泛应用于版权保护、数据防伪和内容认证等领域,特别适用于需要自动化、实时处理以及对复杂攻击环境要求较高的场景。总体而言,深度学习数字水印利用神经

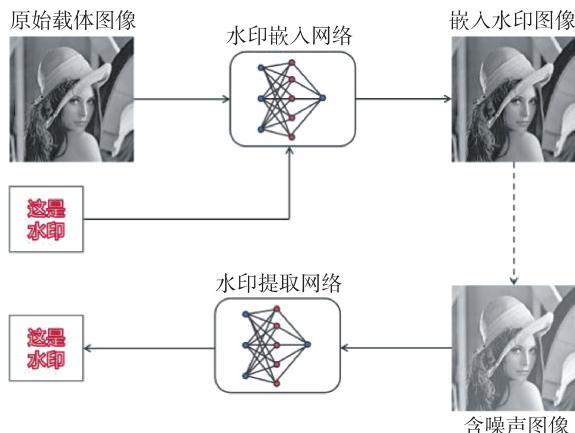


图 2 深度学习数字水印示例

网络的强大学习能力，实现了对传统水印技术的进一步提升，为数字内容保护提供了更加智能和高效的解决方案。

1.2 相关工作

近年来深度学习数字水印方法取得了许多成果。Kandi 等人^[9]于 2017 年首次提出基于深度学习的数字水印方法，而后，多种深度学习的数字水印方案不断涌现：Zhu 等人^[10]提出了一个名为 HiDDeN 的方案，该方案由一个水印嵌入网络、噪声层、水印提取网络和一个对抗网络组成；Mun 等人^[11]提出了一种由残差块组成的 AE 结构神经网络的水印方法；Liu 等人^[12]提出了一种两阶段训练方案 TSDL，即两阶段可分离深度学习，该方案首先对具有对手网络的整个神经网络进行无攻击训练，然后在下一次训练中，通过添加攻击模拟，真对不具有对手网络的提取器进行重新训练。Lee 等人^[13]提出了一种基于卷积神经网络对数字图像进行鲁棒、不可见的盲水印方案。Mehta 等^[14]采用分数阶变换方法，使用广义回归神经网络学习低频分数阶离散余弦变换系数与其领域之间的关系。在医学图像领域，Sinhala 等^[1]提出了基于机器学习的多用途图像水印方案，用于医学图像的数据认证、篡改或伪造定位和 ROI 可逆性等。除了将学习模型应用到数字水印技术之外，还可将数字水印用于深度学习模型的保护。Uchida 等人^[15]提出了使用参数正则化工具在模型参数中嵌入水印的通用框架，通过将水印信息嵌入模型中，使得可以检索此水印信息以证明创建者的所有权。

1.3 本文思路

1.3.1 问题描述

旋转、缩放、剪切等几何攻击往往会引入信号的变形，具体来说图像旋转会改变图像中像素的位置，缩放、剪切会影响图像的尺寸和内容，这类攻击往往是水印技

术面临的难点。传统的整数阶变换在面对这类攻击时，由于水印嵌入点的固定性，鲁棒性表现较差。传统整数阶变换对图像的变换结果高度依赖于图像的空间坐标，当图像发生几何变换时，坐标系统发生改变，会直接影响到变换结果。图像压缩算法通常通过量化高频分量来减少数据量，传统整数阶变换局限于整数次的频率分解，导致水印可能集中嵌入到高频区域，从而在压缩时容易被削弱或破坏。

现有分数阶数字水印方案多是通过手动选择变换阶数。手动选择阶数通常依赖经验或固定规则，难以针对不同类型的信号做出最优选择。不同的信号有不同的时域和频域特性，手动选择的固定值无法适应多样化的信号特征，导致水印嵌入效果不理想，如在压缩攻击中可能会削弱高频信号。因手动选择的阶数可能正好将水印嵌入到受压缩影响较大的频段，导致水印受压缩攻击后失效。

现有深度学习与分数阶数字水印结合的工作大多集中在利用深度学习来优化数字水印的嵌入和提取过程，提升其鲁棒性、不可见性和安全性，针对自适应选择分数阶变换阶数的研究成果还较少，在此方面具有较大的研究空间。

1.3.2 解决思路

本文通过引入深度学习，利用深度学习模型的强大学习能力，学习大量的信号特征和攻击模式，自适应地选择分数阶变换的最优阶数，以最大化水印的隐蔽性和抗攻击能力。

将分数阶水印的灵活嵌入机制与深度学习的强大特征学习能力结合，通过深度学习模型的训练，系统可以在不同的环境和攻击模式下，学习最优的阶数选择策略，以消除手动选择阶数过程中带来的不确定性，并根据数据的变化自适应地调整阶数参数，确保水印在复杂场景中始终保持最佳表现，为数字水印技术提供新的优化手段。

2 基于深度学习的分数阶变换自适应阶数选择模型

本文使用深度学习中的卷积神经网络（CNN）构建分数阶变换数字水印的阶数选择模型，用于分数阶数字水印的水印嵌入过程。

2.1 整体架构设计

如图 3 所示，本文提出的 CNN 模型架构包含特征提取模块、全局特征编码模块和阶数预测模块三个模块。

(1) 特征提取模块：使用卷积层和池化层提取图像的局部特征。每层卷积层采用大小为 3×3 的滤波器，并

在每层后接入最大池化层, 以减小特征图的维度, 逐步提取深层特征。

(2) 全局特征编码: 加入全局平均池化层, 整合特征提取模块输入的高维特征信息, 将其转化为一维特征向量, 输入到阶数选择模块中, 为阶数选择提供更全面的信息。

(3) 阶数选择模块: 采用全连接层将一维特征向量映射到不同的分数阶数类别, 输出层使用 Softmax 作为激活函数, 输出各阶数的概率分布, 选择最高概率的阶数作为最终预测值。

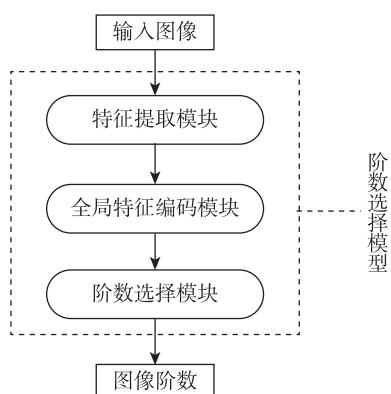


图 3 模型架构示意图

2.1.1 特征提取模块

特征提取模块将输入图像逐步转化为特征图, 提取与图像内容和频率特征相关的信息。该模块通过卷积操作从图像中提取低级到高级的视觉特征, 让网络能够感知图像的边缘、纹理、形状等信息。这些特征在后续的阶数预测中起重要作用。

该模块具体分为多层卷积层和池化层两个部分, 包括 4 层卷积层和池化层组合。随着层数的增加, 网络能够逐步从低级特征学习到高级特征, 为后续的全局特征编码模块提供更加丰富的特征信息。多层卷积层使用大小为 3×3 的卷积核进行局部特征提取, 确保在不引入过多参数的前提下, 捕捉到图像中的边缘和细节信息。每一层卷积都使用 ReLU 激活函数, 使模型具备非线性特征映射能力, 有助于捕获图像特征的非线性变化。在每层卷积层后接入最大池化层, 池化核大小为 2×2 , 通过池化操作减少特征图的分辨率, 降低特征图的维度, 从而减少模型参数量, 并保留关键信息, 防止过拟合, 提升训练效率。

2.1.2 全局特征编码

全局特征编码模块负责将特征提取模块提取到的高维特征整合为低维特征向量, 便于后续的阶数选择模块使用。它能够让模型从整体上理解图像的内容, 生成适

合进行分数阶变换的特征表示。

全局平均池化层会对特征图的每个通道进行平均池化, 将每个通道的特征压缩为一个数值。这样可以将特征图转化为一个一维向量, 用于综合表示整个图像的特征。全局平均池化层相比全连接层参数量更少, 能够减小过拟合风险, 还能保留图像的整体特征信息。

全局平均池化层输出一维特征向量, 直接用于后续的全连接层。这个一维特征向量包含了图像整体信息, 为后续预测最佳阶数提供了一个具有代表性的特征描述。

2.1.3 阶数选择模块

阶数选择模块根据全局特征编码模块编码后的全局特征, 预测适合的分数阶变换阶数, 是整个网络的输出层, 负责将特征向量映射为具体的阶数类别, 输出最适合的分数阶变换参数。阶数选择模块将特征向量映射到最优的阶数类别, 确保模型能够在不同图像内容和攻击条件下自适应选择合适的分数阶变换参数, 以优化水印的鲁棒性和质量。

该模块具体分为全连接层和输出层。全连接层将全局特征向量输入到一个或多个全连接层, 以进一步提取特征向量中的信息。全连接层的激活函数使用 ReLU, 以进一步提取特征的非线性关系。输出层的阶数选择是一个多类别分类问题, 因此输出层采用 Softmax 激活函数, 将各个阶数类别的预测值转换为概率分布。

图 4 所示为模型工作的基本过程, 三个模块协同工作, 使得网络能够从图像特征到分数阶选择进行端到端的映射。在使用过程中, 模型先通过特征提取模块捕获图像的关键特征, 然后通过全局特征编码模块将特征整合为一维表示, 最后通过阶数选择模块选择最优的分数阶数。

2.2 数据集准备

BSDS500 (Berkeley Segmentation Data Set 500) 是加州大学伯克利分校 Computer Vision Group 提供的数据集^[16], 主要用于图像分割和物体边缘检测, 其中包含 500 张自然图像, 涵盖自然场景、动物、建筑、人物等多种图像类型。由于 BSDS500 中的图像包含丰富的边缘、纹理和区域特征, 且容易获取、数据量适中, 因此本文选择了 BSDS500 作为模型的训练和测试数据集。

由于 BSDS500 数据集并没有关于分数阶变换阶数的相关信息, 首先需要对数据集进行预处理, 得到数据集中图像的分数阶变换阶数。本文采用了基于多特征融合的启发式方法^[17] 获取图像的分数阶变换阶数, 提取了图像的边缘特征和纹理特征, 通过一定的权重分配规则计算得到图像最终的分数阶变换阶数。

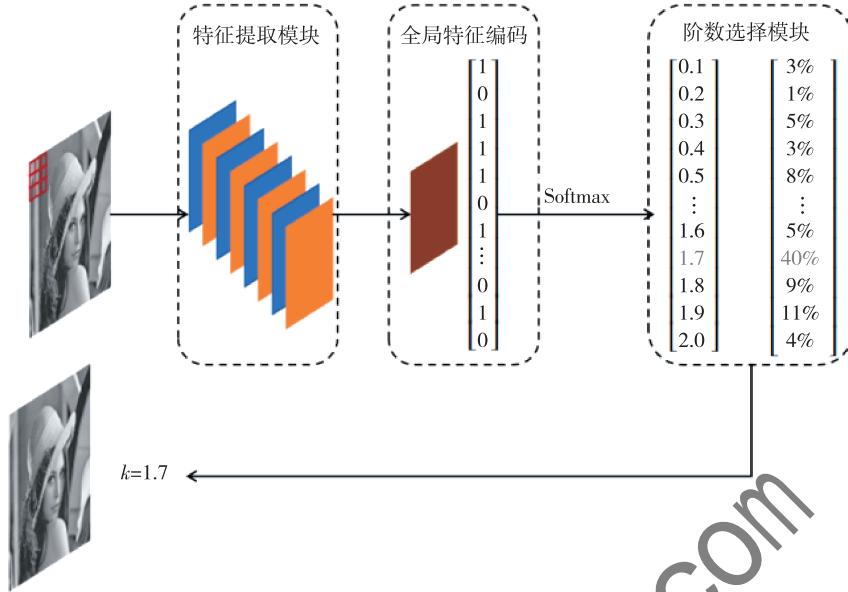


图 4 模型示例

2.3 训练策略

训练策略是构建深度学习模型的关键步骤，对于基于深度学习的分数阶变换自适应阶数选择模型来说，合理的训练策略能够提升模型对图像特征的提取能力和对不同阶数的预测准确性。本文的训练策略包括损失函数的选择、优化器的配置。

(1) 损失函数：在分数阶数选择问题中，模型的任务是预测输入图像的最优阶数，这是一个典型的分类任务。为了衡量模型预测阶数与真实阶数标签之间的差异，损失函数的选择非常重要。对于多类别分类任务，交叉熵损失是最常用的损失函数，它通过计算预测概率分布与真实类别标签之间的差异来指导模型的参数更新。为了防止模型过拟合，可以加入正则化项，使得模型参数保持较小的值，有助于提升模型的泛化能力。正则化损失加入在交叉熵损失的基础上，组合成总损失。

(2) 优化器配置：优化器负责引导模型朝着损失最小的方向更新参数。不同优化器在收敛速度和稳定性上有所差异。Adam (Adaptive Moment Estimation) 是目前较为常用的优化器，它结合了动量和自适应学习率，适合处理稀疏梯度和不稳定的训练数据。Adam 在分数阶自适应选择任务中表现良好，能够快速收敛，且不易陷入局部最优。为了使模型在训练初期快速收敛，同时在后期能够稳定地找到最优解，可以对学习率进行动态调整，每隔固定的迭代次数将学习率进行降低。

3 实验结果分析

该部分给出了实验的评估指标和部分结果分析，以

证明本文所提出方案的有效性。本文使用三个水印评估常用指标来衡量标记图像和恢复的标记图像的质量，包括峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR)、结构相似性指数 (Structural Similarity Index Measure, SSIM) 和归一化相关系数 (Normalised Correlation, NC)。

3.1 评估指标

3.1.1 峰值信噪比

PSNR 主要用于衡量嵌入水印后的载体图像与原始载体图像之间的失真程度，PSNR 越大，说明失真程度越小，即水印的不可见性越好。PSNR 的取值范围是 [0, 100]，其计算公式为：

$$PSNR = 10 \cdot \lg \frac{MAX^2}{MSE} \quad (3)$$

$$MSE = \frac{1}{mn} \sum_i^m \sum_j^n [f(i, j) - g(i, j)]^2 \quad (4)$$

其中 f 表示原始图像， g 表示含水印图像，MAX 表示图像像素的最大值^[18]。

3.1.2 结构相似性指数

SSIM 是对两个图像的亮度、对比度和结构三个量的比较，取值范围是 [0, 1]。SSIM 越大，说明两个图像之间的相似度越高。SSIM 的计算公式为：

$$SSIM = l(X, Y) c(X, Y) s(X, Y) \quad (5)$$

亮度度量函数：

$$l(X, Y) = \frac{2\mu_X\mu_Y + c_1}{\mu_X^2 + \mu_Y^2 + c_1} \quad (6)$$

对比度度量函数：

$$c(X, Y) = \frac{2\sigma_X\sigma_Y + c_2}{\sigma_X^2 + \sigma_Y^2 + c_2} \quad (7)$$

结构对比函数:

$$s(X, Y) = \frac{\sigma_{XY} + c_3}{\sigma_X \sigma_Y + c_3} \quad (8)$$

其中 μ_X 、 μ_Y 分别为图像 X 和 Y 的均值, σ_X 、 σ_Y 分别为图像 X 和 Y 的方差, σ_{XY} 为图像 X 和 Y 的协方差。 c_1 、 c_2 、 c_3 为常数, 为了避免分母为 0 的情况, 通常取 $c_1 = K_1 L$, $c_2 = K_2 L$, $c_3 = c_2/2$, 一般地, $K_1 = 0.01$, $K_2 = 0.03$, $L = 255^{[18]}$ 。

3.1.3 归一化相关系数

NC 用于衡量原始的水印与被提取水印之间的相似程度, 其取值范围是 $[0, 1]$ 。NC 值越大, 则表示原始水印与提取出来的水印相似度越高, 水印算法的鲁棒性越强; NC 值越小, 则相反。NC 的计算公式为:

$$NC = \frac{\sum_{i=1}^m \sum_{j=1}^n (\mathbf{w}(i,j) \times \mathbf{w}'(i,j))}{\sqrt{\sum_{i=1}^m \sum_{j=1}^n [\mathbf{w}(i,j)]^2} \sqrt{\sum_{i=1}^m \sum_{j=1}^n [\mathbf{w}'(i,j)]^2}} \quad (9)$$

其中 \mathbf{w} 表示原始水印, \mathbf{w}' 表示提取出来的水印, m 和 n 分别表示水印图像矩阵的行数和列数^[18]。

3.2 实验结果

本文模型对整个数据集的完整训练次数设置为 50, 以避免过拟合, 批量大小设置为 32, 即模型每次使用 32 张图片进行参数更新。

图 5 所示为模型训练的结果。可见经过训练的基于深度学习的分数阶变换自适应阶数选择模型, 损失函数值逐渐减小并趋于稳定, 模型得到收敛。得到的阶数选择模型能够较好地预测测试集中图片的分数阶变换阶数。

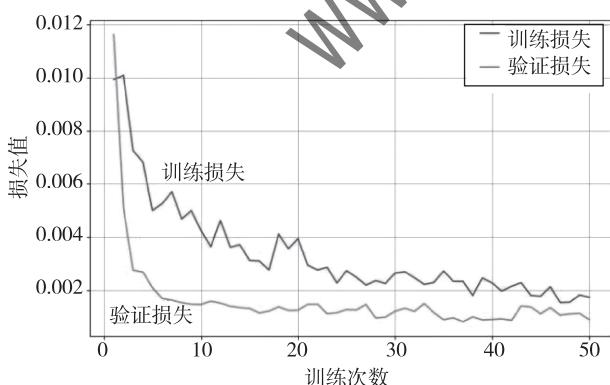


图 5 模型示例

随机选取 10 张图片分别采用整数阶数 $p = 1$, 常用分数阶数 $p = 0.8$ 和模型得到的分数阶 p 进行水印嵌入, 并计算这 10 张图片平均的 PSNR、SSIM 和 NC 值, 得到结果如表 1 所示。

表 1 评估指标结果

	PSNR	SSIM	NC
$p = 1$	13.241	0.1546	0.9924
$p = 0.8$	30.396	0.3306	0.9956
模型所得 p	31.888	0.346	0.9958

可以看到, 相比于整数阶变换和固定分数阶变换, 使用模型进行自适应地选择图像阶数, 指标结果更优。

4 结论

本文基于深度学习建立了分数阶变换数字水印的阶数选择模型, 提出了一种基于深度学习的分数变换域数字水印图像溯源方法。该方案将卷积神经网络引入到分数阶阶数的选择过程, 通过自适应地选择分数阶阶数, 改进了分数阶变换方法手动选择阶数的缺点, 提高了分数阶变换数字水印嵌入方法的隐蔽性和鲁棒性。

由于缺少现有的数据集用于模型训练, 本文采用了基于多特征融合的启发式方法获取数据集的分数阶阶数, 所得的分数阶数据集结果受选择方法影响, 模型训练效果可能受限。未来可以考虑建立更为准确的分数阶阶数数据集, 进一步探讨分数阶选择方法的内在机制。

参考文献

- SINHAL R, ANSARI I A. Machine learning based multipurpose medical image watermarking [J]. Neural Computing and Applications, 2023, 35 (31): 23041–23062.
- PENG F, LIN Z X, ZHANG X, et al. A semi-fragile reversible watermarking for authenticating 2D engineering graphics based on improved region nesting [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 31 (1): 411–424.
- SINGH Y S, SINGH K M, DEV B P. A review of different techniques on digital image watermarking scheme [J]. International Journal of Engineering Research, 2013, 2 (3): 193–199.
- RAY A, ROY S. Recent trends in image watermarking techniques for copyright protection: a survey [J]. International Journal of Multimedia Information Retrieval, 2020, 9 (4): 249–270.
- 马金铭, 苗红霞, 苏新华, 等. 分数傅里叶变换理论及其应用研究进展 [J]. 光电工程, 2018, 45 (6): 5–28.
- TANG M, ZHOU F. A robust and secure watermarking algorithm based on DWT and SVD in the fractional order fourier transform domain [J]. Array, 2022, 15: 100230.
- SINGH H K, SINGH A K. Comprehensive review of watermarking techniques in deep-learning environments [J]. Journal of Electronic Imaging, 2023, 32 (3): 031804.
- HOSNY K M, MAGDI A, EIKOMY O, et al. Digital image watermarking using deep learning: a survey [J]. Computer Science Review, 2024, 53: 100662.

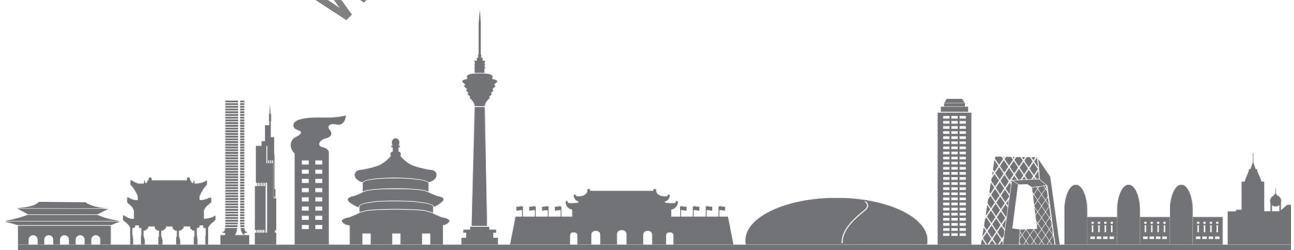
- [9] KANDI H, MISHRA D, Gorthi S R K S. Exploring the learning capabilities of convolutional neural networks for robust image watermarking [J]. Computers & Security, 2017, 65: 247 – 268.
- [10] ZHU J, KAPLAN R, JOHNSON J, et al. HiDDeN: hiding data with deep networks [C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 657 – 672.
- [11] MUN S M, NAM S H, JANG H, et al. Finding robust domain from attacks: a learning framework for blind watermarking [J]. Neurocomputing, 2019, 337: 191 – 202.
- [12] LIU Y, GUO M X, ZHANG J, et al. A novel two-stage separable deep learning framework for practical blind watermarking [C]// Proceedings of the 27th ACM International Conference on Multimedia, 2019: 1509 – 1517.
- [13] LEE J E, SEO Y H, KIM D W. Convolutional neural network-based digital image watermarking adaptive to the resolution of image and watermark [J]. Applied Sciences, 2020, 10 (19): 6854.
- [14] MEHTA R, RAJPAL N. General regression neural network based image watermarking scheme using fractional DCT – II transform [C]//2013 IEEE Second International Conference on Image Information Processing (ICIP-2013). IEEE, 2013: 340 – 345.
- [15] UCHIDA Y, NAGAI Y, SAKAZAWA S, et al. Embedding wa-
- termarks into deep neural networks [C]//Proceedings of the 2017 ACM International Conference on Multimedia Retrieval, 2017: 269 – 277.
- [16] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]// Proceedings of the eighth IEEE International Conference on Computer Vision, 2001, 2: 416 – 423.
- [17] PU Y F, ZHOU J L, YUAN X. Fractional differential mask: a fractional differential-based approach for multiscale texture enhancement [J]. IEEE Transactions on Image Processing, 2010, 19 (2): 491 – 511.
- [18] 王树梅. 数字图像水印技术综述 [J]. 湖南理工学院学报 (自然科学版), 2022, 35 (1): 31 – 36, 68.
(收稿日期: 2024-11-01)

作者简介:

孟燕雨 (1976 -), 男, 本科, 高级工程师, 主要研究方向: 先进网络、数据安全与网络安全、水下空间预警体系。

唐雪译 (2000 -), 女, 硕士研究生, 主要研究方向: 网络空间安全。

李维皓 (1990 -), 女, 博士, 高级工程师, 主要研究方向: 网络安全、隐私保护、攻防效能评估。



版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部